

# 森林火灾风险预测的研究进展及面临的挑战

杨继翔 蒋惠萍 王森 马轩

中央民族大学民族语言智能分析与安全治理教育部重点实验室 北京 100081

中央民族大学信息工程学院 北京 100081

(22302018@muc.edu.cn)

**摘要** 随着全球气候变化和人类活动的加剧,森林火灾事件频发,造成了严重的生态破坏和社会经济损失。森林火灾风险预测作为森林火灾管理和监测的首要措施,具有重要意义。因此,本研究对现有的森林火灾风险预测方法进行了深入分析,按照数据源的不同,将其分为基于地理环境因素、基于遥感与地理信息系统以及基于遥感影像的模型,并详细总结了每类方法的特点,分析了其研究思路、应用范围以及对数据和算法的具体要求。随后,介绍了在森林火灾风险预测领域中相关研究者提出的一些数据集,并对所提及的预测方法的实验结果进行了对比。最后,分析了这3类模型的主要问题,并对未来的研究方向进行了展望。

**关键词:** 森林火灾;火灾预测;遥感;人工智能;机器学习;深度学习

**中图分类号** TP399

## Research Progress and Challenges in Forest Fire Risk Prediction

YANG Jixiang,JIANG Huiping,WANG Sen and MA Xuan

Key Laboratory of Ethnic Language Intelligent Analysis and Security Governance of MOE,Minzu University of China,Beijing 100081,China

School of Information Engineering,Minzu University of China,Beijing 100071,China

**Abstract** With the intensification of global climate change and human activities,forest fire incidents have become increasingly frequent,leading to severe ecological damage and socioeconomic losses.Forest fire risk prediction,as a primary measure for forest fire management and monitoring,has significant importance.Therefore,this study conducts an in-depth analysis of existing forest fire risk prediction methods.These methods are categorized into three types based on different data sources:models based on geographical environmental factors,models based on remote sensing and geographic information systems(GIS),and models based on remote sensing imagery.The characteristics of each method are thoroughly summarized,and their research approaches,application scopes,and specific requirements for data and algorithms are analyzed.Subsequently,this study introduces several datasets proposed by relevant researchers in the field of forest fire risk prediction and compares the experimental results of the mentioned prediction methods.Finally,the major issues associated with the three types of models are analyzed,and future research directions are proposed.

**Keywords** Forest fires,Fire prediction,Remote sensing,Artificial intelligence,Machine learning,Deep learning

## 1 引言

森林火灾长期以来一直是全球性的重要环境与社会问题,它不仅破坏了生态系统的平衡,还威胁到人类的生命和财产安全。近年来,随着全球气候变化和人类活动的加剧,森林火灾事件愈发频繁,呈现出火灾持续时间延长、影响范围扩大以及损失加重的趋势<sup>[1]</sup>。例如,2021年美国加州的“迪克西大火”烧毁了超过46.3万英亩的土地,引发了大范围的空气污染,严重影响了当地居民的健康。同样,2023年加拿大的森林大火持续数月,烧毁了超过7.6万平方公里的土地,造成了严重的生态破坏和空气污染<sup>[2]</sup>。鉴于森林火灾带来的重大威胁,早期森林火灾预测已成为环境科学和公共安全领域中的一个关键研究课题<sup>[3]</sup>。

在森林火灾管理和监测中,首要的措施是进行森林火灾风险预测,其核心任务是预测森林火灾的发生率,即通过分析

火灾风险与气象条件、燃料含量等影响因素之间的关系,预测火灾爆发的概率。有效的火灾风险预测能够划分出高风险区域,对潜在危险区域进行监控并发出预警,从而缩短消防响应时间,减少可能造成的损失和救灾成本。面对当前严峻的全球火灾趋势,我们需要重新评估现有的火灾风险预测策略,分析传统预测模型的局限性,并结合其他学科的方法与更新的数据特征提取技术,综合运用更为科学和技术驱动的方法来减轻火灾带来的影响。本文总结了各种森林火灾风险预测的机器学习和深度学习方法,并根据其数据源的不同,将其分为基于地理环境因素的模型、基于遥感与地理信息系统的模型和基于遥感影像的模型。

本文旨在总结近年来国内外森林火灾风险预测技术,对新提出的预测方法进行分类与归纳,介绍相关研究者提供的公开数据集。与此同时,本文还探讨了森林火灾风险预测中存在的问题,提出了相应的展望和建议。

## 2 森林火灾风险预测理论

### 2.1 问题定义

在森林火灾风险预测研究中,流程的起始点是对各种数据源的广泛收集,这是确保预测模型准确性的基础。随后,在预处理阶段,对数据进行清洗和标准化,这对于后续分析的质量至关重要。在模型构建过程中,采用统计方法和特征工程技术,以挖掘数据中隐藏的模式和关联性,而模型训练则旨在使算法学会如何从这些模式中预测风险。在模型评估阶段,通过严格的测试来确保模型预测的可信度,这一环节是科学验证的关键。经过验证的模型可以用于实际的风险评估,将实时数据转化为风险指数,这些指数为决策提供了重要支持,有助于指导森林管理和应急响应。最后,通过持续的监控和报告,确保所提供的风险预测与实际情况紧密相连,保持预测的实时更新和反馈的准确性。具体研究流程如图1所示。

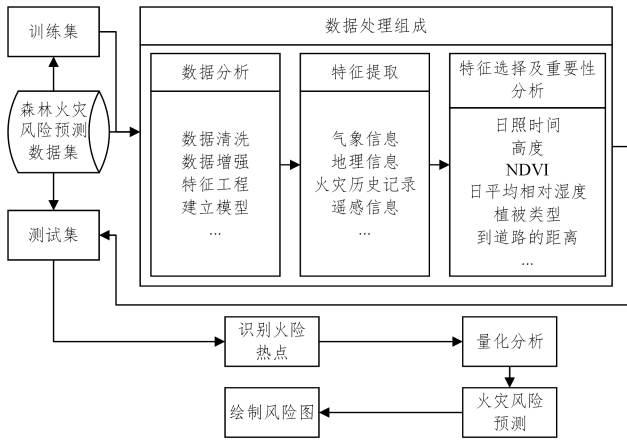


图1 森林火灾风险预测架构图

Fig. 1 Architecture diagram of forest fire prediction

森林火灾风险预测可以视为一个分类问题,其目标是预测某个区域在未来一定时间内发生火灾的概率。为此,我们定义输入空间  $\mathbf{X}$  和输出空间  $\mathbf{Y}$ , 并构建模型  $f$  来实现从输入到输出的映射。

其中,输入空间  $\mathbf{X}$  较为复杂,它一般包括一些环境信息,如地形、植被覆盖和土地利用类型,还包括气象数据(如温度、湿度、风速等)和历史火灾记录等外部信息,如式(1)所示:

$$\mathbf{X} = [x_1, x_2, \dots, x_m] \quad (1)$$

输出空间  $\mathbf{Y}$  表示火灾风险的分类标签。对于二分类问题,输出可以表示为:

$$y \in \{0, 1\} \quad (2)$$

其中,0 表示不发生火灾,1 表示发生火灾。对于多分类问题,输出空间可以表示为多种风险等级(如低风险、中风险和高风险)。

设  $D$  为带有标注标签的  $n$  个数据样本集合,每个样本包括输入向量  $\mathbf{x}$  和对应的输出标签  $y$ :

$$D = \{(\mathbf{x}_i, y_i) \mid i = 1, 2, \dots, n\} \quad (3)$$

使用训练数据集  $D$  来训练模型  $f$ ,其目标是学习输入空间  $\mathbf{X}$  和输出空间  $\mathbf{Y}$  之间的映射关系:

$$f: \mathbf{X} \rightarrow \mathbf{Y} \quad (4)$$

在模型训练过程中,定义损失函数  $L(\mathbf{y}, \hat{\mathbf{y}})$  来衡量模型预测值  $\hat{\mathbf{y}}$  与真实值  $\mathbf{y}$  之间的差异。再通过最优化算法最小化损失函数,调整模型参数  $\theta$  使得预测值与真实值的差异最小,如式(5)所示:

$$\theta = \operatorname{argmin} \sum L(\mathbf{y}_i, f(\mathbf{x}_i; \theta)); \mathbf{X} \rightarrow \mathbf{Y} \quad (5)$$

训练好的模型  $f$  用于对新输入数据  $\mathbf{x}'$  进行预测,得到预测标签  $\mathbf{y}'$ :

$$\mathbf{y}' = f(\mathbf{x}') \quad (6)$$

通过上述过程,森林火灾风险预测模型能够系统化和量化地评估火灾风险,并为应用机器学习和深度学习技术提供基础。这种方法能够在面对复杂多变的环境因素时,实现更高的预测准确性和实时性。

### 2.2 森林火灾风险预测数据来源

森林火灾风险预测是一项跨多个领域的科学研究,其预测的精确性高度依赖于对多源数据收集的信息广度和深度。这些数据涵盖了气象、地形、植被、土地利用、人类活动范围以及历史火灾记录等多个方面,构成了森林火灾风险预测模型的基础。

首先,气象数据是森林火灾风险预测中的关键组成部分,包括温度、湿度、风向、风速和降水等信息。这些数据不仅直接影响火灾的起源和传播,还能帮助预测火势的发展趋势。其次,地形因素也不可忽视,例如地区的坡度、坡向和海拔高度,这些因素会影响局部小气候的形成,进而影响森林可燃物含水率的变化,并决定火势传播的速度和方向。此外,植被类型和土地覆盖状况是评估火灾风险的关键组成部分,通常通过遥感技术获取,能够提供对地表植被状况的简便、有效的测量,从而反映出可燃物的分布和状态。历史火灾记录同样是非常重要的数据来源,提供了关于火灾发生模式、趋势、地区特征和响应措施有效性的宝贵信息,为模型的建立和验证提供了依据。最后,人类活动对森林火灾的影响也不容忽视,如与道路、河流等基础设施的距离、人口密度和土地利用变化等因素,都会对火灾风险产生影响。

通过组合不同维度的数据,可以构建出更为精准和全面的森林火灾风险预测模型。这些模型不仅能够评估当前的火灾风险,还能预测未来的风险趋势,从而为火灾防治和应对提供科学依据。

### 2.3 森林火灾风险预测数据集

由于森林火灾的形成机制较为复杂,涉及的影响因子众多,因此,森林火灾风险预测数据集的建立也相对复杂。大多数数据集由相关研究者自行构建。本文对该领域内的数据集进行了广泛调研,并对较为重要的数据集进行了总结,具体内容如表1所列。

表1 森林火灾风险预测的数据集概览

Table 1 Overview of datasets for forest fire prediction

文献	数据集	数据类型	空间分辨率
[4]	GEODATA DEM-9S	地形数据(坡度、海拔和坡向数据)	1 km
[5]	TerraClimate	气象数据(温度、湿度、风速和降水)	小于 5 km
[6]	Wildfires	天气数据、植被(NDVI)、火灾样本(烧毁区域、热异常图)	250 m, 500 m
[7]	Sentinel-2	火灾样本(火灾前后的遥感图像,按破坏程度分类)	10~60 m
[8]	WildfireDB	火灾样本(历史野火发生情况)、植被数据、地形数据、天气数据	30~375 m

(续表)

文献	数据集	数据类型	空间分辨率
[9]	MTBS	火灾样本(火灾后和火灾前大地遥感卫星大气顶部图像、dNBR 图像、RdNBR 图像)	30 m
[10]	NWDS	火灾样本(火灾前和火灾后掩模、二维火灾数据)、植被(NDVI)、人口密度、天气、地形(海拔高度)	1 km
[11]	FireRisk	标有火灾风险等级的遥感图像	320 m

### 3 森林火灾风险预测的研究进展

#### 3.1 基于地理环境因素的森林火灾风险预测模型

基于地理环境因素的森林火灾风险预测模型是一种利用统计学和机器学习技术进行数据特征提取的数学模型,旨在通过大量环境数据和历史火灾事件信息,评估特定地区森林火灾发生的可能性和潜在危害程度。这些模型通常采用多元回归分析、决策树、支持向量机、人工神经网络等方法,将气象、地形、植被覆盖等地理环境因素与森林火灾的发生概率进行关联建模。在模型构建过程中,需要对地理环境因素进行有效的数据采集、处理和特征提取,并对历史火灾事件进行分析,以确定影响火灾发生的关键因素。随后,通过合适的数学模型,将这些地理环境因素与火灾发生的概率或风险水平建立数学关系,形成预测模型。在模型训练完成后,通常将近期或历史环境数据输入模型,以预测未来一段时间内的森林火灾风险情况。

初期研究构建的模型主要依赖于基于规则的模型和数学统计方法,通常还需要结合部分社会经济指标、人类活动数据和历史火灾数据。由于数据处理能力的限制,不可能使用物理模型或实验模拟模型来监测大尺度和长时间尺度的火灾风险,并且这些数据有时需要近乎实时。因此,森林火灾风险预测在很大程度上依赖于创建经验和统计模型,其准确性取决于模型挖掘出火灾贡献变量之间复杂非线性相互作用的能力,以及数据的可用性和数据质量。Jaiswal 等<sup>[12]</sup>的研究表明,基于地理环境数据的火灾风险模型与实际火灾发生率之间存在密切关联。基于这一发现,许多火灾风险模型采用了各种数据分析技术,并根据与火灾相关的参数进行构建。Guo 等<sup>[13]</sup>利用 Ripley 的 K 函数和逻辑斯蒂回归(Logistic Regression Model, LR)模型分析了 2000 年至 2008 年中国福建省森林火灾的空间格局和驱动因素。这些驱动因素参考了年均气象因素、地形因素、基础设施因素以及社会经济因素等,从而确定了火灾的空间分布,并揭示了驱动因素对火灾发生的综合和个体影响。最后,研究通过统计模型和绘制风险地图预测了中国福建的火灾点火模式。

在此基础上,各国政府机构构建了各自的火灾评级系统。例如,加拿大森林火灾危险评级系统(Canadian Forest Fire Danger Rating System, CFDRS)<sup>[14]</sup>是一种融合气象数据和地面观测数据的经典模型,广泛应用于北美地区的火灾预测和管理。美国农业部则利用火灾计划分析系统(Fire Planning and Analysis System, FPA)<sup>[15]</sup>中的大型火灾模拟系统生成的林火可能性和强度的空间估计数据,结合空间燃料、植被信息以及历史火灾发生点的地理位置数据,开发了一套用于描述林火潜在风险的地图。这套系统用于协助预测和管理林火风险,为林火预防和控制策略提供了科学依据。

数值天气预报和气候模型的不断进步带来了更高的地理分辨率和更长的预报时间<sup>[16]</sup>,这意味着可以获得更精确、更

多样化的数据,从而有效提升了预测森林火灾发生的准确性。这些进步为以数据为中心的森林火灾预测建模方法提供了理想的条件,并为解决许多研究难题带来了新的可能性。因此,近年来,将机器学习方法应用于森林火灾风险预测的研究受到了广泛关注。Qu 等<sup>[17]</sup>通过使用自动学习框架分析天气数据,研究了火灾发生的预测,准确率达到 87%。Lin 等<sup>[18]</sup>提出了一种模糊推理和大数据分析算法来评估火灾风险,并计算了定量的潜在火灾风险,使用了中国南京市的天气、地点和时间数据,其预测森林火灾的准确率达到了 75%。Bui 等<sup>[19]</sup>采集了越南林同省热带森林的环境数据,使用了 DFP-MnBp-Ann 模型。该方法基于人工神经网络,采用了差分进化(DFP)和迷你匹配反向传播(MnBp)的新型混合训练算法,预测准确率达到了 88.43%。Gao 等<sup>[20]</sup>利用吉林省 2000—2019 年的气象因子数据,使用随机森林(Random Forest, RF)、支持向量机(Support Vector Machine, SVM)、地理加权 Logistic 回归模型、Lasso 回归模型和 Logistic 模型,对研究区域进行了火灾风险预测研究,准确率分别为 88.7%, 87.7%, 86.0%, 85.0% 和 84.6%。研究结果表明,RF 和 SVM 相较于 Logistic 模型的准确率分别提升了 4.84% 和 3.66%,显示了机器学习在处理庞大森林火灾因子数据方面的强大特征提取能力,并有效支持了气象因子在地理环境因素中是影响森林火灾风险评估的主要因素的观点<sup>[21]</sup>。Adhikari 等<sup>[22]</sup>使用多层感知机(Multilayer Perceptron, MLP)和模糊逻辑技术分析多传感器数据、温度、烟雾密度和一氧化碳密度,以预测起火可能性,研究中的预测误差达到了  $10^{-4}$ 。Liang 等<sup>[23]</sup>从加拿大自然资源部发布的加拿大国家火灾数据库(CNFDB)中收集数据,以气象因子为输入,采用反向传播神经网络(Back-propagation, BP)、循环神经网络(Recurrent Neural Network, RNN)和长短期记忆(Long Short-Term Memory, LSTM)建立了预测模型。在这些分类方法中,LSTM 的准确率最高,为 90.9%。

虽然基于环境因素的森林火灾风险预测模型在评估由自然条件引发的火灾风险方面表现出色,但这些方法存在一些局限性。首先,这些模型难以充分预测由人为因素或极端天气事件引发的火灾,因为它们主要侧重于气象因素,而缺乏对植被、地形、人类活动、社会经济影响及其他生物物理和生态因素的综合分析。其次,气象因素对火灾发生的影响机制十分复杂,火灾的发生也与人类活动密切相关,这使得单纯依赖统计分析进行评估预测的可靠性较低。此外,由于数据源的限制,这些模型无法有效覆盖广阔的地理区域,并实时处理大量数据。同时,在数据收集和处理方面还存在时间和空间上的局限性。因此,为了提高预测的准确性和实用性,结合遥感技术是必要的。遥感技术可以提供高分辨率、实时性强的环境数据,为模型提供更丰富的信息,从而改善森林火灾风险预测的效果。

#### 3.2 基于遥感与地理信息系统的森林火灾风险预测模型

基于遥感与地理信息系统的森林火灾风险预测模型是一

种将环境监测与空间分析技术相结合的方法。该模型可以从地面观测站、遥感卫星和气象模型中获取各类多维度信息,并利用遥感的强大空间数据处理能力,整合和分析多种地理环境因素,如气候条件(温度、湿度、降雨量、风速等)、地形(坡度、坡向、高程等)和植被(类型、密度、湿度等)数据。通过对不同数据层的叠加和分析,模型能够快速识别具有较高火灾风险的区域。例如,通过分析地形数据,可以确定哪些区域由于坡度或坡向而更易发生火灾;结合植被数据,可以评估不同类型植被的燃烧潜力;再结合气候数据,可以有效分析极端天气事件(如干旱和高温)带来的火灾发生风险。

早期提出的研究主要基于 Logistic 回归(LR)统计模型。Chang 等<sup>[24]</sup>以我国黑龙江省作为森林火灾的研究对象,选择了多种气象、地形、人为和植被因素进行分析。气象因素包括每日降雨量、最高气温、最低气温、平均气温、平均风速、空气湿度和年均气温;地形因素包括坡度、坡向和高程;人为因素包括人口密度、距离最近的道路、河流和村庄的距离;植被因素包括植被类型。研究利用 ArcGIS 软件,从历史火灾记录中筛选了超过 3000 组实验数据,通过变量筛选和 Logistic 模型训练构建了模型,其中年平均降雨量对模型的解释力最强。经验证,该模型的 AUC 值为 0.7。Pan 等<sup>[25]</sup>利用 2002—2012 年山西省的 MODIS 遥感数据集,基于森林火灾空间分布和影响因素,构建了空间森林火灾风险模型。该模型选择的因素包括高程、坡度、距离最近道路的距离、可燃物含水率、陆地表面温度、归一化植被指数(NDVI)以及全局植被湿度指数。通过基于空间抽样建立的 Logistic 模型,生成了森林火灾概率分布图,并将山西省划分为零、低、中、高和极高火灾风险区。经验证,模型的 AUC 值达到了 0.757。

在此研究基础上,研究者们开始使用多种统计方法来预测森林火灾。Suryabagavan 等<sup>[26]</sup>采用了多重标准决策分析方法(Multi-criteria Decision-Making, MCDM),对影响研究区域火灾风险的因素按重要性贡献度顺序进行了分析,并生成了埃塞俄比亚西南部哈伦纳地区的森林火灾风险等级地图,将火灾风险区域分为极高风险、高风险、中度风险和低风险 4 类。具体来说,该研究利用遥感与地理信息系统采集地貌数据和邻近因素并作为森林火灾风险易感性的参数。在整合这些地理环境因素之前,研究者根据层次分析法(Analytic Hierarchy Process, AHP)评估了各因素的权重和火灾贡献度得分。利用九点重要性分级法,将因素的重要性分为较低(极低、非常低、较低和中等)和较高(同等、中等、较高、非常高和极高),并制定了一个重要性比较矩阵。为了得出最合适的权重集,研究者使用权重计算了上述重要性比较矩阵的主特征向量。根据主特征向量的计算结果,确定了每个参数的相对重要性顺序,依次为植被类型、坡度、海拔、地势、居民点和道路。随后,将所有重新分类的因子层进行加权叠加分析,生成了森林火灾易感性地图。

随着研究的进展,研究者们开始使用机器学习算法来处理遥感与地理信息系统采集的庞大数据。机器学习算法能够有效处理和分析大规模、多维度的数据集,从而提供更精确的火灾风险评估。

Huesca 等<sup>[27]</sup>结合了来自 MODIS 卫星图像的季节性遥感数据、气候数据和燃料类型,利用火势指数(Fire Potential Index, FPI)分析了不同地区的季节性火势变化。Rajeev

等<sup>[28]</sup>提出了一种综合地形、气候和燃料数据的火灾预测方法,其中燃料数据来源于 MODIS 卫星数据。该研究使用随机森林(Random Forest, RF)算法来探索这些变量与森林火灾之间的关系,并据此构建了一个森林火灾潜在风险数据集。Sayad 等<sup>[29]</sup>将大数据、遥感和数据挖掘算法(神经网络和支持向量机)结合起来,处理从 MODIS 图像中收集的大数据,并从中提取特征来预测森林火灾的发生。具体而言,他们利用经过预处理的 MODIS 数据创建了一个数据集,该数据集基于 3 个与植被状态相关的参数:归一化差异植被指数(NDVI)、地表温度(LST)和热异常,取得了 98.32% 和 97.48% 的预测准确率。Malik 等<sup>[30]</sup>开发了一种基于机器学习和大数据的系统化火灾风险预测模型,通过分析加利福尼亚州圣地亚哥的卫星数据、气象数据和历史火灾数据,使用集合模型对森林火灾风险进行预测,准确率达到 100%。Kaur 等<sup>[31]</sup>引入了一个数据集成框架,整合了来自遥感卫星、地面气象站和其他来源的数据,创建了一个涵盖加拿大阿尔伯塔省 18 年的综合天气数据库,包含了气象数据和火灾历史数据,采用了随机森林(RF)、极限梯度提升(XGBoost)和多层感知器(MLP)等机器学习方法来评估森林火灾风险预测性能。结果显示,其 ROC-AUC 评分为 87.2%,灵敏度为 75%。Yang 等<sup>[32]</sup>使用 FIRMS(Fire Information for Resource Management System)<sup>[33]</sup>的热点数据作为预测模型训练和评估的标签,并利用 Landsat 7 提供的遥感数据预测印度尼西亚的森林火灾,模型实现了超过 81% 的接收器工作特性(ROC)。Rubí 等<sup>[34]</sup>的研究使用了多个机器学习模型,并使用从巴西政府开放数据中收集的数据集来预测森林火灾的蔓延和行为。该数据集包括 5 个监测站对气候特征的观测、过去 20 年火灾的卫星数据,以及其他地形、水文和人为特征,如城市化指数、与河流和道路的距离以及归一化差异植被指数(NDVI)。不同机器学习模型在预测森林火灾方面的准确率如下:AdaBoost 模型为 91%,随机森林(RF)模型为 88%,神经网络(ANN)模型为 86%,支持向量机(SVM)模型为 81%。Vasconcelos 等<sup>[35]</sup>通过分析栅格地理信息系统中的数据,包括发生日期、地理坐标、起火原因、土地利用和燃烧面积等,创建了一个预测森林火灾起火概率的模型。研究使用逻辑回归(LR)和多层感知器(MLP)对这些数据进行了评估。结果显示,在有火灾和无火灾情况下,神经网络(ANN)的准确率分别为 75.5% 和 87.8%,而逻辑回归的准确率分别为 78.8% 和 74%。Tuyen 的研究<sup>[36]</sup>采用了局部加权学习(LWL)算法与集合学习技术相结合的方法来预测越南义安省国家公园的森林火灾易发性。研究通过地理空间数据库,利用包含 56 条历史火灾记录和 9 个解释变量的数据,训练了独立的 LWL 模型和衍生的集合模型。模型性能评估时使用了多种统计性能标准,包括接收器工作特征曲线下面积(AUC)。结果显示,CG-LWL 和 Bagging-LWL 模型的训练性能最高,AUC 为 99.3%。此外,Dagging-LWL 组合模型的 AUC 为 98.3%,在预测整个研究区域的火灾易感性空间模式方面优于其他模型。

基于遥感与地理信息系统的森林火灾风险预测模型是当前研究的主流模型,其优势在于整合了多种数据源,包括气象数据、地形数据和植被覆盖数据等。通过遥感技术获取的高分辨率数据,能够提供更为详细的地理信息,从而使预测更加

全面和准确。此外,该模型可以进行空间分析,对特定地理区域进行精细化的火灾风险评估,识别出火灾风险较高的区域,有助于采取有针对性的防范措施。然而,这种模型也存在一些挑战与限制。首先,数据收集是一个复杂且耗时的过程,需要大量的环境数据和历史火灾事件数据,这增加了模型建立的成本。其次,由于不同地区的环境特征和火灾发生机制可能存在差异,同一模型在不同地理区域的预测效果可能不尽相同,缺乏通用性,需要进行个性化定制或调整。最后,建立和应用该模型需要具备一定的地理信息系统和遥感技术的专业知识,对技术人员的要求较高。

### 3.3 基于遥感影像的森林火灾风险预测模型

目前,基于遥感影像的火灾预测系统主要通过探测热红外电磁波辐射强度来监控地面火情,直接观测地表是否发生热异常现象,并据此估算其强度,从而实现了对已发生火灾的蔓延及强度的预测。多光谱遥感影像中包含丰富的波段信息,其中微波遥感可以提供地表干燥程度,热红外遥感可以提供地表温度,而可见光遥感反演的植被指数等生态指标可以更新可燃物分布地图<sup>[37]</sup>。这些技术为野火监测和管理提供了前所未有的机会和能力。随着向公众开放的卫星产品和航空遥感项目数量的增加,获取遥感影像变得更加便捷。同时,光学传感器技术的发展显著提升了遥感影像的分辨率,使地表特征的识别更加清晰和精确,从高分辨率遥感影像中可以获得早期森林火灾风险预测的关键信息。

在此背景下,计算机视觉领域的研究者已开始探索如何将遥感图像应用于火灾风险预测。Pourghasemi等<sup>[38]</sup>使用增强回归树分类器计算森林火灾风险的易发性,使用两幅卫星图像(OLI和MODIS)进行评估,得出的准确率为89%。Shmuel等<sup>[39]</sup>进行了一项预测森林火灾风险发生率和规模的研究,使用随机森林(RF)、极限梯度提升(XGBoost)、多层感知器(MLP)、逻辑回归(LR)和线性回归等多种机器学习模型,分析了2015年全球 $0.25^{\circ} \times 0.25^{\circ}$ 区域的月分辨率烧毁面积数据集。研究结果表明,XGBoost的准确率为94%,LR的准确率为81%,RF的准确率为89%,MLP的准确率为90%。

在现有研究中,已经提出了多种基于遥感图像的深度学习方法。其中,一些方法利用图像分类和分割技术来识别森林火灾风险区域,从而预测火灾蔓延。例如,Zhang等<sup>[40]</sup>提出了一种名为FBC-ANet的网络架构,该架构能够从图像中提取更多与火灾相关的有价值特征,从而更好地分割火灾区域。其在数据集FLAME上的分割准确率达到92.19%,F1分数为90.76%,IoU达到83.08%。Abdusalomov等<sup>[41]</sup>则提出了一种基于Detectron2的深度学习森林火灾风险检测方法,识别森林火灾风险区域并进行火灾分类,其精度达到了99.3%。然而,这些方法通常需要大量的计算资源和时间。

另一些方法则将深度学习技术应用于森林火灾风险预测,通过提取遥感图像中的火灾风险特征来预测火灾发生的

可能性。例如,Hodges等<sup>[42]</sup>使用卷积神经网络(CNN)方法评估遥感图像、燃料类型和天气条件,以预测森林火灾风险的时间-空间演变,研究得出的平均精确度为97%,F1分数为93%。Lin等<sup>[43]</sup>提出了一种基于LSTNet的新型森林火灾风险易感性空间预测方法,通过遥感卫星和地理信息系统获取影响森林火灾风险的因素,并利用皮尔逊相关分析和多重共线性检验估计其相关性,该模型能够有效利用空间背景信息和森林火灾风险因子的周期性,准确度达到94.1%。Miao等<sup>[44]</sup>提出了一种基于窗口的新型变压器架构的时间序列火灾预测方法,考虑了13个影响因素,并辅以双时间序列作为火灾风险特征输入策略,预测准确率达到了91.56%。

此外,最近Shen等<sup>[11]</sup>提出了一种构建森林火灾风险等级与遥感影像之间映射关系的简单新方法。该方法的构建原理基于一个假设,即遥感影像中包含的空间地理信息能够反映火灾风险的程度。例如,通过识别遥感影像中的森林树木种类、土地利用类型以及与人类活动区域的相对距离等信息,可以间接反映火灾发生的难度。该方法从森林火灾的空间特性出发,专注于在空间维度上提取图像特征,以构建描述遥感图像与地球表面火灾风险之间映射关系的数据集。该数据集包含91872幅 $320 \times 320$ 像素的高分辨率正射遥感图像,这些图像被标注为7个不同的火灾风险等级:零、极低、低、中、高、极高和水体,为森林火灾风险评估提供了标注数据。FireRisk数据集由美国国家农业影像计划(The National Agriculture Imagery Program,NAIP)项目采集,涵盖了美国多种地理和气候区域的地表正射遥感图像,确保了模型在多样化环境中的适应性和鲁棒性。实验结果表明,使用在ImageNet<sup>[45]</sup>上预先训练的MAE<sup>[46]</sup>模型可以达到65.29%的准确率,证实了仅使用遥感数据进行火灾评估的有效性。与传统的火灾评估方法相比,该研究的实现过程更为简单,泛化效果更好。该研究能够有效弥补其他方法在数据收集和处理方面存在的时间和空间局限性、不同地区火灾风险特征不一致,以及预测模型缺乏通用性的问题,并为未来研究提供了新思路。

基于遥感影像的森林火灾风险预测技术是一种创新方法,其结合了遥感技术和计算机视觉图像处理技术。该方法利用卫星和航空传感器捕获的影像数据,提供了关于地表覆盖、植被状态、人类活动区域等重要信息。与传统依赖地面和机载系统采集环境数据的系统相比,遥感技术在森林火灾监测和预测领域展现了独特的性能优势。虽然在某些情况下,遥感系统的灵敏度可能不如基于地理环境因素的系统,但其对小规模火灾的检测能力表明,即使在较低空间分辨率下,遥感技术仍能有效监测火灾。此外,遥感技术能够捕捉到细微的地表变化,使用高分辨率的卫星影像产品数据可以使火灾风险评估更加精准。该方法还具有较强的通用性,能够解决不同地区火灾风险特征不一致的问题。

上述森林火灾风险预测模型总结如表2所列。

表2 森林火灾风险预测的模型和研究结果  
Table 2 Models and research results of forest fire risk prediction

文献	数据源和特征选择	方法	结果
[11]	NAIP正射影像遥感图像	MAE	准确率:65.29%
[29]	来自MODIS图像、NDVI、LST和热异常的大数据	ANN,SVM	准确率:98.32%(ANN),97.48%(SVM)
[30]	圣地亚哥的卫星、气象和历史火灾数据	集合建模和R-CNN	准确率:100%,93%
[31]	遥感卫星、气象站提供的数据	RF,XGBoost,MLP	ROC-AUC:87.2%;灵敏度:75%(XGBoost)

(续表)

文献	数据源和特征选择	方法	结果
[32]	FIRMS 热点数据、Landsat 7 遥感数据	CNN, LSTM	ROC > 81%
[34]	气候特征、卫星数据、NDVI	ML	准确率: 91% (AdaBoost), 88% (RF), 86% (ANN), 81% (SVM)
[35]	栅格 GIS 数据, 包括发生日期、土地利用、烧毁面积	LR 和 MLP	准确率: 75.5% (MLP), 87.8% (LR)
[36]	包含历史火灾记录和解释变量的地理空间数据库	LWL 算法与集合学习相结合	AUC: 99.3%
[38]	遥感图像 (OLI 和 MODIS)	增强回归树分类器	准确率: 89%
[39]	全球烧毁面积数据集	RF, XGBoost, MLP, LR	准确率: 94% (XGBoost), 89% (RF), 90% (MLP), 81% (LR)
[40]	数据集 FLAME	FBC-ANet	准确率: 92.19%; F1 分数: 90.76%; IoU: 83.08%
[41]	有无火灾标签的遥感图像	基于 Detectron2 的深度学习方法	精度: 99.3%
[42]	遥感图像、燃料类型、天气条件	CNN	准确率: 97%; F1: 93%
[43]	遥感图像和地理信息系统获取的因素	LSTNet	准确率: 94.1%
[44]	环境因素辅以时间序列	Transformer	准确率: 91.56%

## 4 未来研究方向

针对不同方法, 本文分析了存在的问题并对未来发展方向进行了展望。

基于地理环境因素的森林火灾风险预测模型依赖于地理环境数据的采集, 其面临的主要挑战包括以下几点:

1) 预测能力局限: 该模型在评估由自然条件引发的火灾风险方面表现出色, 但难以充分预测由人为因素或极端天气事件引发的火灾。这主要是因为这些模型主要侧重于气象因素, 缺乏对植被、地形、人类活动、社会经济影响以及其他生物物理和生态因素的综合分析。

2) 地理环境因素的复杂影响机制: 地理环境因素对火灾发生的影响机制复杂, 而火灾的发生也与人类活动密切相关, 单纯依赖统计分析进行评估预测的可靠性较低。

3) 数据源限制: 由于数据源的限制, 这些模型无法有效覆盖广阔的地理区域, 并实时处理大量数据。此外, 在数据收集和处理方面也存在时间和空间上的局限性。

因此, 未来研究应结合多种环境和人为因素进行综合分析, 可以通过引入更多变量, 如社会经济因素、人类活动数据等, 提高模型对不同类型火灾的预测能力。为了提高预测的准确性和实用性, 结合遥感技术是必要的。遥感技术可以提供高分辨率、实时性强的环境数据, 为模型提供更丰富的信息。此外还需要促进跨学科合作, 整合气象学、地理学、生态学等领域的知识, 开发更为全面和精确的预测模型。

基于遥感与地理信息系统的森林火灾风险预测模型大大提升了数据源的来源和覆盖面积, 但也面临以下挑战:

1) 数据收集成本高: 数据收集是一个困难且耗时的过程, 需要大量的环境数据和历史火灾事件数据, 增加了模型构建的成本。

2) 通用性问题: 由于不同地区的环境特征和火灾发生机制可能存在差异, 同一模型在不同地理区域的预测效果可能不尽相同, 缺乏通用性, 因此需要进行个性化定制或调整。

3) 专业技术要求高: 建立和应用该模型需要具备一定的地理信息系统和遥感技术的专业知识, 对技术人员的要求较高。

需要从以下方面进行针对性改进。1) 数据集成与优化, 未来研究应探索更高效的数据集成与处理方法, 降低数据收集和处理的成本。同时, 优化模型以提高其对不同地理区域的适应性。2) 自动化技术发展, 开发更智能的自动化数据处

理和分析技术, 减少对高技能技术人员的依赖, 提升模型的普及性和应用性。3) 个性化模型定制, 研究针对不同区域和环境特点的个性化模型定制方法, 以提高模型在不同地理区域的适用性和预测准确性。

基于遥感影像的森林火灾风险预测模型是一个较为新兴的研究方向, 其有效结合遥感信息、地理信息和计算机视觉处理方法, 大大提高了信息挖掘能力。然而, 该模型在实际应用中仍然面临一些挑战:

1) 实时数据提供的局限性: 该模型在实时数据提供方面存在一些局限性, 主要表现为定位、重新定位和数据传输过程中的时延。这种时延可能会影响火灾风险的及时预测和响应, 限制了模型在紧急情况下的有效性。

2) 数据集的不足: 目前, 与林火检测相关的官方基准数据集较缺乏, 研究者需要自行创建标注数据集。这不仅增加了研究难度和不确定性, 还可能导致不同研究之间的数据不一致性, 影响结果的可比性和模型的通用性。

3) 预测算法的局限性: 现有的预测算法对遥感影像中的地物信息提取不够充分, 无法有效建立遥感影像与火灾风险之间的映射关系。这种局限性导致模型的预测效果受限, 特别是在处理复杂地形和多样化土地覆盖时。

4) 数据质量的依赖性: 该模型对数据质量的依赖性较强, 遥感影像的分辨率和质量直接影响模型的预测效果。虽然高分辨率的卫星影像产品可以提高预测的准确度, 但获取这些数据的成本较高, 限制了模型在大范围内的应用。

5) 计算复杂度和硬件要求: 视觉图像处理的计算复杂度较高, 对所需算力的要求也较高。这意味着实际应用中, 对硬件性能的要求较高, 可能增加部署和维护的成本, 并对应用场景产生限制。

因此, 未来的研究应着重于减少遥感影像数据在定位、重新定位和传输过程中的时延, 以提高实时数据提供的效率。同时, 建立与林火检测相关的标准化基准数据集, 统一数据标注和算法评估标准, 增强研究的可比性和可靠性。此外, 进一步优化预测算法, 增强地物信息提取的准确性, 建立更有效的遥感影像与火灾风险的映射模型也至关重要。研究还应关注降低视觉图像处理的计算复杂度, 提升算法的运行效率, 并探索硬件性能方面的优化方案, 以适应实际应用的需求。随着遥感技术的不断进步, 特别是在精确度和响应速度方面的提升, 基于遥感影像的森林火灾风险预测模型将实现质的飞跃, 为大尺度环境变化研究提供更强大的工具和支持。

**结束语** 森林火灾风险预测的核心特点是利用多源数据和综合数据分析方法,实现对火灾风险的精确评估和动态预测。综合来看,结合遥感技术的基于遥感与地理信息系统、基于遥感影像的两类森林火灾风险预测模型,凭借其全球监测能力和良好的精确度,在森林火灾风险预测的关键环节中占据着不可或缺的地位,其在技术创新和应用领域的扩展方面具有广阔的研究和实践前景。同时,现有的森林火灾风险预测模型为研究者提供了多样性和选择余地,研究者可以根据实际需求和研究区域的数据特征选择适合的预测策略。综上所述,现阶段森林火灾风险预测任务虽然已经取得了一定成果,但仍有许多问题亟待解决。

### 参 考 文 献

- [1] BAI N, WANG B, WU Y D, et al. Overview of global forest fires in 2021[J]. *Fire Science and Technology*, 2022, 41(4): 705.
- [2] WU Y Y, SHU L F, WANG M Y, et al. Overview of forest fires in the world in recent years[J]. *Temperate Forestry Research*, 2022, 5(4): 49-54.
- [3] BARMPOUTIS P, PAPAIOANNOU P, DIMITROPOULOS K, et al. A review on early forest fire detection systems using optical remote sensing[J]. *Sensors*, 2020, 20(22): 6442.
- [4] HUTCHINSON M, STEIN J, STEIN J, et al. GEODATA 9 s DEM and D8: Digital Elevation Model Version 3 and Flow Direction Grid 2008 [EB/OL]. <http://pid.geoscience.gov.au/dataset/ga/66006>.
- [5] ABATZOGLOU J T, DOBROWSKI S Z, PARKS S A, et al. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958—2015[J]. *Scientific data*, 2018, 5(1): 1-12.
- [6] SAYAD Y O, MOUSANNIF H, AL MOATASSIME H J. Predictive modeling of wildfires: A new dataset and machine learning approach[J]. *Fire Safety Journal*, 2019, 104: 130-146.
- [7] MONACO S, GRECO S, FARASIN A, et al. Attention to fires: Multi-channel deep learning models for wildfire severity prediction[J]. *Applied Sciences*, 2021, 11(22): 11060.
- [8] SINGLA S, MUKHOPADHYAY A, WILBURM, et al. Wildfire-db: An open-source dataset connecting wildfire occurrence with relevant determinants[C]// *NeurIPS Thirty-fifth Annual Conference on Neural Information Processing Systems*. 2021.
- [9] HU X, ZHANG P, BAN Y. Large-scale burn severity mapping in multispectral imagery using deep semantic segmentation models[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 196: 228-240.
- [10] HUOT F, HU R L, GOYAL N, et al. Next day wildfire spread: A machine learning dataset to predict wildfire spreading from remote-sensing data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-13.
- [11] SHEN S, SENEVIRATNE S, WANYAN X. Firerisk: A remote sensing dataset for fire risk assessment with benchmarks using supervised and self-supervised learning[C]// *International Conference on Digital Image Computing: Techniques and Applications (DICTA)*. IEEE, 2023: 189-196.
- [12] JAISWAL R K, MUKHERJEE S, RAJU K D, et al. Forest fire risk zone mapping from satellite imagery and RS[J]. *International journal of applied earth observation and geoinformation*, 2002, 4(1): 1-10.
- [13] GUO F, SU Z, WANG G, et al. Wildfire ignition in the forests of southeast China: Identifying drivers and spatial distribution to predict wildfire likelihood[J]. *Applied Geography*, 2016, 66: 12-21.
- [14] STOCKS B J, LAWSON B D, ALEXANDER M E, et al. The Canadian forest fire danger rating system: an overview[J]. *The Forestry Chronicle*, 1989, 65(6): 450-457.
- [15] FINNEY M A, MCHUGH C W, GRENFELL I C, et al. A simulation of probabilistic wildfire risk components for the continental United States[J]. *Stochastic Environmental Research and Risk Assessment*, 2011, 25: 973-1000.
- [16] SIMARD S J. Fire severity, changing scales, and how things hang together[J]. *International Journal of Wildland Fire*, 1991, 1(1): 23-34.
- [17] QU J, CUI X. Automatic machine learning framework for forest fire forecasting[C]// *Journal of Physics: Conference Series*. IOP Publishing, 2020, 1651(1): 012116.
- [18] LIN H, LIU X, WANG X, et al. A fuzzy inference and big data analysis algorithm for the prediction of forest fire based on rechargeable wireless sensor networks [J]. *Sustainable Computing: Informatics and Systems*, 2018, 18: 101-111.
- [19] BUI D T, VAN LE H, HOANG N D. RS-based spatial prediction of tropical forest fire danger using a new hybrid machine learning method[J]. *Ecological Informatics*, 2018, 48: 104-116.
- [20] GAO B, SHAN Y, LIU X et al. Prediction and driving factors of forest fire occurrence in Jilin Province, China[J]. *Journal of Forestry Research*, 2024, 35(21): 21-26.
- [21] LI D. Study on the relationship between forest fires and meteorological factors in key areas of Sichuan Province[D]. Beijing: Beijing Forestry University, 2013.
- [22] ADHIKARI D, CHEN W, GUO Y, et al. Wildfire Progression Prediction and Validation Using Satellite Data and Remote Sensing in Sonoma, California[C]// *2023 IEEE International Conference on Service-Oriented System Engineering (SOSE)*. IEEE, 2023: 262-271.
- [23] LIANG H, ZHANG M, WANG H. A neural network model for wildfire scale prediction using meteorological factors[J]. *IEEE Access*, 2019, 7: 176746-176755.
- [24] CHANG Y, ZHU Z, BU R, et al. Predicting fire occurrence patterns with loRStic regression in Heilongjiang Province, China [J]. *Landscape Ecology*, 2013, 28(10): 1989-2004.
- [25] PAN J, WANG W, LI J. Building probabilistic models of fire occurrence and fire risk zoning using loRStic regression in Shanxi Province, China[J]. *Natural Hazards*, 2016, 81(3): 1879-1899.
- [26] SURYABHAGAVAN K V, ALEMU M, BALAKRISHNAN M. RS-based multi-criteria decision analysis for forest fire susceptibility mapping: a case study in Harena forest, southwestern Ethiopia[J]. *Tropical Ecology*, 2016, 57(1): 33-43.
- [27] HUESCA M, LITAGO J, PALACIOS-ORUETA A, et al. Assessment of forest fire seasonality using MODIS fire potential: A time series approach[J]. *Agricultural and Forest Meteorology*, 2009, 149(11): 1946-1955.
- [28] JAISWAL R K, MUKHERJEE S, RAJU K D, et al. Forest fire

- risk zone mapping from satellite imagery and RS[J]. International Journal of Applied Earth Observation and Geoinformation, 2002, 4(1): 1-10.
- [29] SAYAD Y O, MOUSANNIF H, AL MOATASSIME H. Predictive modeling of wildfires: A new dataset and machine learning approach[J]. Fire safety journal, 2019, 104: 130-146.
- [30] MALIK A, JALIN N, RANI S, et al. Wildfire Risk Prediction and Detection using Machine Learning in San Diego, California [C]// 2021 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/IOP/SCI). IEEE, 2021: 622-629.
- [31] KAUR P. Forest fire prediction using heterogeneous data sources and machine learning methods[D]. University of Waterloo, 2023.
- [32] YANG S, LUPASCU M, MEEL K S. Predicting forest fire using remote sensing data and machine learning[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2021: 14983-14990.
- [33] FIRMS N. Fire information for resource management system [EB/OL]. <https://firms.modaps.eosdis.nasa.gov/map>.
- [34] RUBI J N S, DE CARVALHO P H P, GONDIM P R L. Application of machine learning models in the behavioral study of forest fires in the Brazilian Federal District region[J]. Engineering Applications of Artificial Intelligence, 2023, 118: 105649.
- [35] DE VASCONCELOS M J P, SILVA S, TOMEM, et al. Spatial prediction of fire ignition probabilities: comparing loRStic regression and neural networks[J]. Photogrammetric engineering and remote sensing, 2001, 67(1): 73-81.
- [36] TUYEN T T, JAAFARI A, YEN H P H, et al. Mapping forest fire susceptibility using spatially explicit ensemble models based on the locally weighted learning algorithm[J]. Ecological Informatics, 2021, 63: 101292.
- [37] CHEN X F, LIU L, LI J G, et al. Application and research progress of satellite remote sensing fire point monitoring[J]. Journal of Remote Sensing, 2020, 24(5).
- [38] POURGHASEMI H R, GAYEN A, LASAPONARA R, et al. Application of learning vector quantization and different machine learning techniques to assessing forest fire influence factors and spatial modelling [J]. Environmental research, 2020, 184: 109321.
- [39] SHMUEL A, HEIFETZ E. Global wildfire susceptibility mapping based on machine learning models [J]. Forests, 2022, 13(7): 1050.
- [40] ZHANG L, WANG M, DING Y, et al. FBC-ANet: A semantic segmentation model for UAV forest fire images combining boundary enhancement and context awareness [J]. Drones, 2023, 7(7): 456.
- [41] ABDUSALOMOV A B, ISLAM B M D S, NASIMOV R, et al. An improved forest fire detection method based on the detector2 model and a deep learning approach [J]. Sensors, 2023, 23(3): 1512.
- [42] HODGES J L, LATTIMER B Y. Wildland fire spread modeling using convolutional neural networks [J]. Fire technology, 2019, 55: 2115-2142.
- [43] LIN X, LI Z, CHEN W, et al. Forest fire prediction based on long-and short-term time-series network [J]. Forests, 2023, 14(4): 778.
- [44] MIAO X, LI J, MU Y, et al. Time Series Forest Fire Prediction Based on Improved Transformer [J]. Forests, 2023, 14(8): 1596.
- [45] DENG J, DONG W, SOCHER R, et al. Imagenet: A large-scale hierarchical image database [C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009: 248-255.



**YANG Jixiang**, born in 2000, postgraduate. His main research interests include computer applications and remote sensing image processing.



**JIANG Huiping**, born in 1975, Ph. D, professor, Ph. D supervisor. Her main research interests include artificial intelligence, affective computing and intelligent education.